



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사 학위논문

합성신호 데이터와 딥러닝 모델을 이용한  
음향방출 검사 방법에 관한 연구

Research on Acoustic Emission Testing Method  
Using Synthetic Signal Data and Deep Learning  
Models

울산대학교 대학원

전기전자컴퓨터공학과

이 상 인

합성신호 데이터와 딥러닝 모델을 이용한  
음향방출 검사 방법에 관한 연구

지도교수 김종면

이 논문을 공학석사 학위 논문으로 제출함

2023년 8월

울산대학교 대학원

전기전자컴퓨터공학과

이 상 인

이상인의 공학석사 학위 논문을 인준함

심사위원장	권 영 근	인
심사위원	김 중 면	인
심사위원	조 동 식	인

울 산 대 학 교 대 학 원

2023 년 8 월

## [국문 요약]

# 합성신호 데이터와 딥러닝 모델을 이용한 음향방출 검사 방법에 관한 연구

음향방출(Acoustic Emission, AE) 검사 기술은 배관, 다리, 항공기, 선박 등 다양한 구조물의 안전과 지속 가능성을 확보하는 데 널리 사용되고 있다. 그러나 기존의 AE 검사 방법들은 환경 요인에 따른 성능 제한과 사용자 경험에 기반한 환경 변수 조정이 필요한 문제로 인한 한계가 있다. 이러한 한계를 극복하기 위해 합성신호 데이터를 활용한 딥러닝 기반 AE 임펄스 신호 검출 방법에 대한 연구를 수행했으며, 이를 통해 기존 방법들의 문제점을 개선할 수 있는 새로운 접근 방식을 제안한다.

먼저, 본 연구에서는 다양한 환경 조건을 시뮬레이션하는 AE 합성신호 데이터 생성 모델을 개발하였다. 이 모델은 다양한 환경 조건에서 발생할 수 있는 음향방출 특징을 고려하여 합성 데이터를 생성함으로써 딥러닝 알고리즘의 학습에 활용할 수 있는 풍부한 데이터를 제공한다. 생성된 데이터를 바탕으로 딥러닝 기반 AE 임펄스 신호 검출 모델을 학습시키는 과정에서는 다양한 네트워크 구조와 학습 기법들을 실험하고 비교하였다. 최적의 구조와 기법을 찾아내어 높은 성능과 안정성을 달성한 모델을 구축하였다.

학습된 모델을 활용해 실제 배관 검사에 적용하여 효용성을 검증하는 단계에서는, 기존의 고정식 임계치 기반 방법 및 AE 버스트 모니터링(Acoustic Emission Burst Monitoring, ABM) 방법과 비교하여 배관 검사 성능을 평가하였다. 결과적으로 제안된 방법은 기존 방법들에 비해 준수한 검사 성능을 보였고, 기존 방법에서 발생하는 여러 문제점을 개선하였다.

딥러닝 알고리즘의 활용으로 인해 매개변수가 없어짐으로써 환경 변수 조정에 대한 의존성이 줄어들었으며, 다양한 환경에서 보다 정확한 임펄스 신호 검출이 가능해졌다. 또한, 딥러닝 기반 방법은 기존 방법들보다 노이즈가 많은 환경에서도 적응적이며 안정적인 성능을 보였다.

연구의 결과를 실제 산업 현장에 적용할 경우, 구조물의 안전과 지속 가능성에 대한 평가를 더욱 정교하게 수행할 수 있을 것으로 기대된다. 이를 통해 구조물의 유지보수 비용과 시간을 절감하고, 안전 사고의 위험을 감소시킬 수 있을 것이다.

결론적으로, 본 연구는 합성신호 데이터를 활용한 딥러닝 기반 음향방출 임펄스 신호 탐지 방법을 제안하여 기존의 검사 방법의 한계를 극복하고, 구조물의 안전과 지속 가능성을 향상시키는 데 기여할 것으로 기대된다. 이러한 접근 방식은 AE 검사 기술의 발전과 다양한 분야에 적용할 수 있는 토대를 마련해 줄 것이다.

# 목차

[국문 요약]	I
[목차]	II
[그림 목차]	III
[표 목차]	IV
<b>1. 서론</b>	<b>1</b>
1.1. 연구 목적 및 필요성	1
1.2. 논문의 구성	2
<b>2. 관련 연구</b>	<b>3</b>
2.1. 음향방출 시험	3
2.1.1. 음향방출 신호 특징	3
2.2. 기존 배관 검사 기술	5
2.2.1. 청음식 누수 탐지	5
2.2.2. 음향방출 센서 기반 누수 탐지	5
2.3. 신호처리	7
2.3.1. 산포도 분석	7
2.3.2. 신호 변조 및 복조	8
2.4. 딥러닝	9
2.4.1. DeconvNet	10
2.4.2. 양방향 LSTM	11
<b>3. 음향방출 임펄스 신호 검출</b>	<b>13</b>
3.1. 합성신호 데이터 생성 알고리즘	13
3.2. 임펄스 신호 검출 모델	16
3.3. 검출 모델 학습 결과	19
3.4. 실제 구조물 검사 적용성 평가	22
<b>4. 적용 시스템</b>	<b>26</b>
4.1. 지하배관 상태 모니터링 시스템	26
<b>5. 결론</b>	<b>29</b>
[참고 문헌]	V
[영문 요약]	VI

## 그림 목차

그림 2-1. 초음파 검사와 음향방출 비교 .....	3
그림 2-2. 음향방출 신호 종류 .....	4
그림 2-3. 음향방출 신호 주요 특징 .....	4
그림 2-4. 청각을 이용한 배관 누설탐지 방법 .....	5
그림 2-5. 신호의 도달 시간차를 이용한 누수 위치 추정 기법 .....	6
그림 2-6. 영역 분할을 이용한 누수 위치 추정 기법 .....	6
그림 2-7. 사분위수 분석 개념 .....	7
그림 2-8. 다양한 분포에서의 사분위수 적용 예시 .....	8
그림 2-9. Tukey Fences 이상치 탐지 개념도 .....	8
그림 2-10. AM 신호 변조 예시 .....	9
그림 2-11. DeconvNet 모델 구조 .....	10
그림 2-12. VGG-16 모델 구조 .....	10
그림 2-13. Unpooling, Deconvolution 연산 추상도 .....	11
그림 2-14. 양방향 LSTM 모델 구조 .....	12
그림 3-1. 이중 지수 함수 그래프 .....	13
그림 3-2. 지수 함수에서의 Tukey 기준 .....	14
그림 3-3. 임펄스 신호 변조 개념도 .....	15
그림 3-4. 제안 모델의 구조 .....	16
그림 3-5. 제안 모델의 입출력 모형 .....	16
그림 3-6. 출력 값 후처리를 통한 분류 결과 .....	17
그림 3-7. 실험에 사용된 모델의 그래프 .....	18
그림 3-8. 학습 데이터 생성 프로세스 .....	18
그림 3-9. 학습 데이터 생성 결과 예시 .....	19
그림 3-10. 검증 데이터의 임펄스 검출 결과 .....	20
그림 3-11. 학습 배치에 따른 성능 곡선 .....	21
그림 3-12. 산업용 배관 테스트베드 현장 .....	22
그림 3-13. 산업용 배관 테스트베드 도면 .....	22
그림 3-14. 데이터 수집 시스템 구성도 .....	23
그림 3-15. 테스트베드 데이터 수집 절차 .....	23
그림 3-16. 누수 위치 추정 분포도 .....	24
그림 4-1. 지하배관 상태 모니터링 시스템 구성도 .....	26
그림 4-2. 지하배관 상태 모니터링 메인 화면 .....	27
그림 4-3. 지하배관 규칙 기반 진단 도구 화면 .....	28

## 표 목차

표 3-1. 학습 데이터 생성에 사용된 매개변수 범위 .....	19
표 3-2. 학습 결과 성능 지표 .....	21
표 3-3. 실험에 사용된 테스트베드 매개변수 .....	22
표 3-4. 누수 위치 추정 결과 비교표 .....	25
표 4-1. 지하배관 상태 모니터링 서버 규격 .....	26
표 4-2. 지하배관 상태 모니터링 시스템 개발 환경 .....	26



# 1. 서론

## 1.1. 연구 목적 및 필요성

현대 공공 지하 시설물의 대부분은 배관으로, 국내 하수도 보급률은 93.6%이다. 국내 인구 90% 이상이 공공 하수관의 서비스 대상이다. 그러나 하수관의 노후화 상태가 현재 상당한 수준이며, 이로 인한 지반 침하 등의 문제가 지속적으로 발생하고 있다[1]. 이러한 지하 시설물의 안전과 지속 가능성을 확보하기 위한 중요한 요소 중 하나는 정기적인 유지보수와 검사이다. 배관에서 발생하는 손상과 결함은 강도와 내구성 약화를 초래하며, 대규모 사고나 재난의 원인이 될 수 있다. 이에 따라 구조물 손상 감지를 위한 기술 연구가 지속적으로 이루어지고 있다.

음향방출(Acoustic Emission, AE) 검사는 구조물의 결함 감지에 사용되는 대표적인 기술 중 하나이다. 이 기술은 구조물에서 발생하는 균열, 누출 및 부식 등 비정상 상태 변화로 인해 발생한 에너지가 탄성과 형태로 방출되는 것을 감지하여 구조물 상태 평가에 활용하는 것을 말한다. 배관에서의 대표적인 AE 검사 기술은 예로 누수 탐지, 누출원 위치 추정 기술 등이 있다. 배관을 따라 센서로 전파되는 AE 신호는 누출원으로부터 방출된 임펄스 신호를 포함하고 있으며 이러한 신호는 감쇄 및 속도에 대한 파동 분산 규칙을 따르고 있다[2]. 따라서 누출 위치 추정 기술은 다중 센서간 신호가 도달하는 시간차(Time Difference of Arrival, TDOA)에 크게 의존하게 된다.

실시간으로 TDOA를 검출하는 방법에는 가장 일반적인 방법인 임계치를 고정하여 검출하는 방법[3]과 적응형 임계치를 기반한 AE 버스트 모니터링(Acoustic Emission Burst Monitoring, ABM) 방법[4] 등이 있다. 배관에서 발생하는 AE 신호는 플랜지 접합점의 진동, 내부 유체 교란 위치, 외부의 무작위 충돌 등과 같은 다양한 원인으로부터 발생한다. 기존의 임계치 고정 방법은 이러한 노이즈에 취약하며 경험에 의해 임계치를 조절해주어야 하는 등 제한적인 성능을 보인다. 반면, ABM 방법은 적응형 임계값 설정 기법을 제안하여 이를 해결하였지만, 적응형 임계값 계산에 필요한 매개변수를 수동으로 입력해야 하기에 여전히 전문가의 판단과 경험이 반영되어야 좋은 성능을 기대할 수 있다는 한계점이 있다.

이러한 한계점을 극복하기 위해 딥러닝 기술을 활용한 음향방출 임펄스 신호 검출 방법은 좋은 대안이 될 수 있으며 이에 대한 연구가 필요하다. 딥러닝은 인공지능 분야에서 널리 사용되는 기술로, 복잡한 패턴을 학습하여 예측 및 분류 작업을 수행할 수 있다. 따라서, 음향방출 검사에서 임펄스 신호 검출을 위한 딥러닝 모델 활용 방법을 탐구하는 것이 본 연구의 주요 목표이다.

또한, 딥러닝 모델을 학습하고 검증하기 위해서는 수 많은 샘플 데이터를 필요로 하기에 음향방출 합성신호 데이터 생성 알고리즘을 개발하고 다양한 환경 조건을 모사한 합성신호 데이터를 생성하고자 한다. 이를 통해 테스트베드로부터 얻을 수 있는 데이터 다양성의 한계와 학습 데이터 부재 문제를 극복할 수 있다.

마지막으로, 생성된 데이터를 바탕으로 음향방출 임펄스 신호 검출 모델을 학습시키고 실제 구조물 검사에 적용 가능한지에 대한 타당성을 검토하는 것이 본 연구의 최종 목표이다.

본 연구의 결과는 구조물의 안전성과 지속 가능성 확보에 중요한 역할을 할 것으로 기대된다. 더불어 기존의 검출 방법에서 나타났던 제한적인 성능과 문제점을 개선하여 음향방출 검사 기술의 발전에 기여하려 한다. 이를 통해, 현대 지하 시설물 및 인프라의 안전성과 지속 가능성 확보에 기여할 수 있을 것을 전망한다.

## 1.2. 논문의 구성

본 논문은 다음과 같이 구성되어 있다. 2 장에서는 음향방출 시험, 기존 배관 검사 기술, 신호처리, 딥러닝에 대한 관련 연구를 서술하고, 3 장에서는 음향방출 신호 합성과 임펄스 신호 검출 방법 및 실험 결과 및 분석 내용을 기술한다. 4 장에서는 본 연구 결과와 기술을 적용한 시스템에 대해 소개하며, 5 장에서 본 논문의 결론을 맺는다.

## 2. 관련 연구

### 2.1. 음향방출 시험

음향방출(Acoustic Emission, AE)이란 구조물이 변형 또는 파괴 시에 발생하는 진동을 탄성과 형태로 방출되는 현상이며, 탄성파를 음향방출 센서로 검출하고 평가하는 방법을 “음향방출 시험”이라고 한다. 음향방출 신호는 물질이 파괴되기 전부터 작은 변형이나 균열 진행 과정에서 발생하는데, 이 신호의 발생 경향을 진단함으로써 구조물의 결함을 조기에 발견하고 대응할 수 있다.




그림 2-1. 초음파 검사와 음향방출 비교

음향방출 시험(Acoustic Emission Testing)은 물질이 변형을 일으킬 때 탄성파를 발생하는 음향방출의 특성에 착안하여 개발된 비파괴 검사의 일종으로, 기존 비파괴 검사와 달리 시스템 결함이나 파단의 발생을 조기에 예측할 수 있는 최신 진단 기술이다. 또한, 매질을 타고 전파하는 탄성파를 음향방출 센서로 읽어 취득된 음향방출 신호에, 탄성파를 추출하기 위한 신호 증폭, 잡음 제거 등의 복합 처리 과정을 거쳐 데이터를 구축할 수 있다. 이렇게 추출된 복합 신호 형태의 데이터에 재료별 탄성파 특성, 증폭과 횡과 요소, 파형의 굴절, 감쇄, 반사 등을 종합적으로 고려하여 해석하면 결함 가능성을 조기에 진단하고 조치할 수 있다. 따라서 센서가 결함원과 수십 미터 이상의 거리를 두고 있더라도 결함을 탐지해낼 수 있고 다른 비파괴 검사 기술에 비해 상대적으로 미세한 결함까지 검출이 가능하다.

#### 2.1.1. 음향방출 신호 특징

AE 신호는 일반적으로 그림 2-2 와 같이 돌발형(Impulse type) 신호와 연속형(Continuous type) 신호로 구분된다. 재료 내의 균열 성장 및 파손에 의해 발생하는 AE는 대부분 돌발형 신호로 나타나고, 유체의 누설, 재질의 변형 등에 의해 발생하는 AE는 연속형 신호와 혼합되어 나타난다. 음향방출 시험을 진행할 때 수행할 수 있는 신호 분석은 전체 파형을 온전히 분석하는 방법과 원신호로부터 특징 파라미터를 추출하여 분석하는 방법이 있다. 음향방출 신호는 일반적으로 큰 진폭을

가진 돌발형(Impulse type) 신호가 대부분이므로 그림 2-3 과 같이 AE 특징 파라미터는 돌발형(Impulse type) 신호를 중심으로 정의되고 있다[5].



그림 2-2. 음향방출 신호 종류

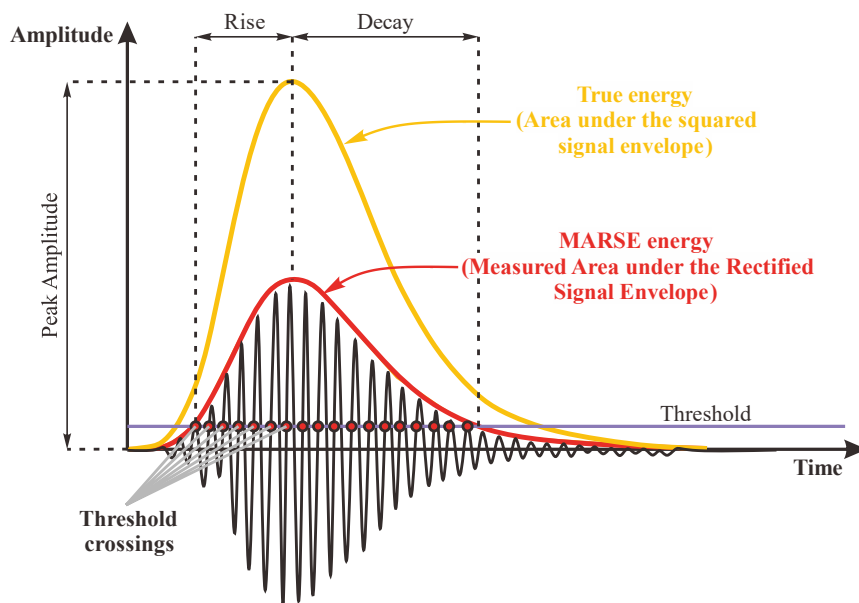


그림 2-3. 음향방출 신호 주요 특징

- 최고진폭(Peak Amplitude): 신호의 최대 강도를 나타내며, 일반적으로 전압(V) 또는 음향방출 단위(AE)로 표시된다. 최고 진폭은 소재나 구조물의 결함 크기와 관련이 있다.
- 과도시간(Rise Time): 신호가 시작되는 순간부터 최고 진폭에 도달하기까지 걸리는 시간을 말한다. 이 시간은 신호의 초기 성장률을 나타내며, 일반적으로 마이크로초( $\mu\text{s}$ ) 단위로 측정된다.
- 감쇄시간(Decay Time): 신호의 최고 진폭에서 임계치까지 감소하는데 걸리는 시간을 의미한다. 이 시간은 신호의 감쇄 속도와 비례하며, 마찬가지로 마이크로초( $\mu\text{s}$ ) 단위로 측정된다.

- 지속시간(Duration): 신호가 시작되는 순간부터 완전히 소멸되기까지의 전체 시간을 의미한다. 이 시간은 신호의 지속성을 나타내며, 밀리초(ms) 또는 마이크로초( $\mu$ s) 단위로 측정된다.
- 에너지(Energy): 신호의 전체 에너지를 나타내며, 일반적으로 아주 작은 단위인 피코존드(PJ) 또는 나노존드(NJ) 단위로 측정된다. 에너지는 신호의 강도와 지속시간에 따라 달라지며, 이를 통해 소재나 구조물의 결함에 대해서 심각성을 평가할 수 있다.

## 2.2. 기존 배관 검사 기술

지난 수년간 노후화된 지하매설 배관은 부식과 파손으로 인한 누수, 화재, 과열 등의 사고 위험성이 높아졌다. 이러한 위험은 사회에 심각한 피해와 영향을 끼칠 수 있기 때문에, 배관 유지보수 과정에서 누수 탐지의 중요성이 크게 대두되고 있다. 본 연구에서는 음향방출 임펄스 신호 검출 방법을 제안하였으며, 이 방법이 실제 구조물 검사 기술에 응용 가능한지를 검증하기 위해 배관 누수 탐지 기술을 활용하였다. 따라서 기존의 배관 검사 기술에 관한 선행 연구를 진행하였다.

### 2.2.1. 청음식 누수 탐지

지하 매설 배관의 누수 기술은 전통적으로 청음봉과 청음식 누수탐지기와 같은 도구를 이용해 전문 인력의 청각에 의존한 검사 방법이 있다. 주로 소구경으로 깊게 매설되지 않은 배관에 대해 오랫동안 사용되어 왔다. 이러한 방법은 주변 소음이 적은 조용한 환경에서는 누설위치를 추정할 수 있으나, 사람의 청각에 의존하기 때문에 일정 규모 이상의 누수가 발생해야 소리로 탐지가 가능하므로 정밀한 누수 검사가 필요할 때는 활용되기가 어렵다.



(a) 청음봉을 이용한 방법



(b) 청음식 누수탐지기를 이용한 방법

그림 2-4. 청각을 이용한 배관 누설탐지 방법

### 2.2.2. 음향방출 센서 기반 누수 탐지

음향방출 센서를 통한 배관의 누수 탐지는 일종의 비파괴 검사이다. 배관 시스템에 물리적 손상을 주지 않으면서 지속적인 데이터 수집을 통해 실시간으로

정밀한 누수 탐지가 가능하고 누수 발생 시 조기에 발견하여 즉각 대응이 가능하다. 또한, 배관에 부착된 다수의 센서를 이용해 누수 위치 추정이 가능하다는 장점이 있다. 음향방출 센서를 통한 배관의 누수 위치 추정 기술은 도달 시간차 기법과 영역 분할 기법으로 나뉜다.




그림 2-5. 신호의 도달 시간차를 이용한 누수 위치 추정 기법

“도달 시간차 기법”은 배관에 부착된 다수의 센서를 사용하여 각 센서에서 검출된 돌발형 신호(임펄스)의 도달 시간차를 이용하는 기법이다. 센서의 부착위치와 대상 구조물에서의 탄성과 전파속도를 이용하여 임의의 위치에서 발생한 누수 위치를 검출할 수 있다. 그림 2-4 와 같이 임의의 위치에 대한 위치 추정 식은 (1)로 정의된다.

$$d = \frac{1}{2}(D - V \times \Delta t), \quad (1)$$

여기에서,  $D$ 는 센서간의 거리,  $V$ 는 전파 속도,  $\Delta t$ 는 센서  $T_1$ ,  $T_2$  간 신호의 도달 시간차를 가리킨다. 가스, 수도 배관 등에서의 누수를 검출하는데 적합한 방법으로, 두 센서를 1 차원 선 위에 배치하여 센서 사이의 음향방출 신호를 통해 누수 위치를 검출하게 된다.




그림 2-6. 영역 분할을 이용한 누수 위치 추정 기법

구조물의 형태가 복잡하거나 탄성과 전파속도 측정에 어려움이 있는 경우에는 탄성과 도달 시간차를 이용한 위치 추정 기법을 적용하기 어렵다. 이럴 경우, “영역 분할 기법”을 사용하면 아주 정확한 위치 추정은 불가능하지만 부착된 센서별로 분할된 영역에서 측정된 각 신호의 크기를 비교하여 대략적인 손상 영역의 선정이

가능하다. 즉, 그림 2-6 과 같이 센서 부착 위치에 따라 영역을 나누고 측정된 신호의 크기를 계속 비교해 가면서 결함이나 누출이 발생한 영역을 좁혀갈 수 있다.

## 2.3. 신호처리

본 연구에서는 합성신호 생성 방법을 제안하였으며, AM 변조 기술, 산포도 분석 지표에 기반한 Tukey Fences 방법 등이 활용되었다.

### 2.3.1. 산포도 분석

산포도는 데이터가 얼마나 퍼져 있는지 설명하는 지표이다. 사분범위, 분산, 범위, 표준편차 등을 지표로 사용한다. 이는 일반적으로 값이 높을수록 데이터가 넓게 분포해 있으며, 값이 낮을수록 데이터가 조밀하게 분포해 있는 것을 의미한다.

$$Range(X) = \text{범위} = \max(X) - \min(X) \quad (2)$$

$$Var(X) = \text{분산} = \sum [X - avg(X)]^2 \quad (3)$$

$$\sigma_x = \text{표준편차} = \sqrt{Var(X)} \quad (4)$$

사분위수(Quartile)는 크기를 기준으로 나열한 자료를 네 등분하는 관측 값이다.

- Q1 = 1 사분위수 = 25 percentile = Lower quartile
- Q2 = 2 사분위수 = 50 percentile = 중앙값(Median)
- Q3 = 3 사분위수 = 75 percentile = Upper quartile
- Q4 = 4 사분위수 = 100 percentile

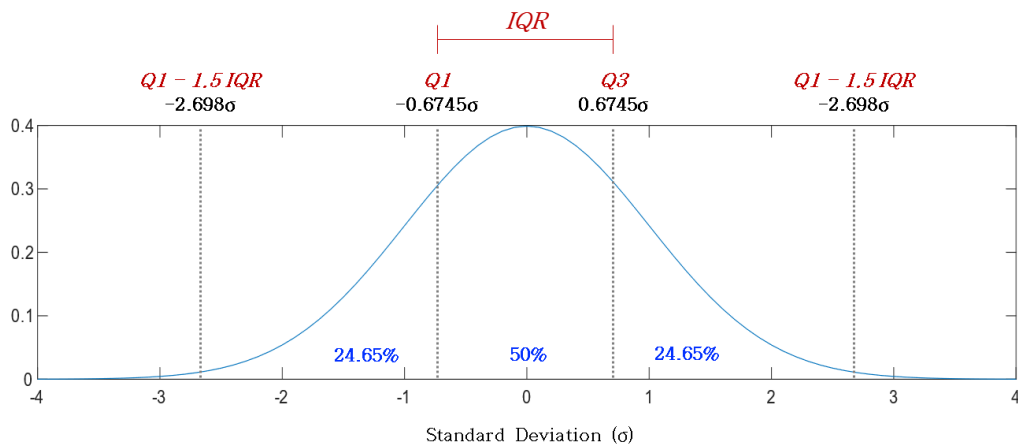


그림 2-7. 사분위수 분석 개념




그림 2-8. 다양한 분포에서의 사분위수 적용 예시

사분범위(Interquartile range, IQR)는 전체 자료의 50%를 포함하는 범위이며, 사분위수를 이용한 표현식은 (5)로 정의된다.

$$IQR = Q3 - Q1, \quad (5)$$

데이터의 중앙값(Median)을 기준으로 흩어진 정도를 나타내는 지표이며, 극단적인 값들에 의한 영향을 비교적 덜 받아서 안정적인 분석을 가능하게 해준다는 장점을 가지고 있다. 이상치 탐지, 데이터 분포 파악, 데이터 정제, 통계 추론 등 다양한 분석 기술에서 널리 활용된다[6].




그림 2-9. Tukey Fences 이상치 탐지 개념도

사분범위를 기반으로 이상치를 측정하는 방법은 대표적으로 Tukey Fences 가 있다. Tukey Fences 방법에서는 그림 2-9 와 같이 데이터가 “ $Q1 - 1.5 \times IQR$ ”에 미달하거나, “ $Q3 + 1.5 \times IQR$ ”을 초과하면 이상치로 정의한다[6].

### 2.3.2. 신호 변조 및 복조

변조(Modulation) 및 복조(Demodulation)는 통신 시스템에서 전력과 대역폭 효율성을 최적화하기 위해 사용되는 기술이다. 변조는 정보를 포함하는 저주파수 전기 신호를 고주파 교류 신호로 변환하는 과정이며, 복조는 교류 신호를 원래의 전기 신호로 되돌리는 과정이다. 주요 변조 방법에는 진폭 변조 방식(Amplitude Modulation, AM)과 주파수 변조 방식(Frequency Modulation, FM)이 있다.



진폭 변조(AM) 방식은 일반적인 변조 신호를 전자기파 형태로 변환하는 방법으로, 이 과정에서 입력 신호의 주파수가 증가하는 특성을 보인다. AM 변조 수식은 다음과 같이 주어진다.

$$y(t) = [1 + m(t)]c(t), \quad (6)$$

여기서  $c(t)$ 는 캐리어 신호,  $m(t)$ 는 변조 신호를 나타낸다. 반면 주파수 변조(FM) 방식은 높은 주파수의 신호를 변조 신호에 적용하되, 진폭은 일정하게 유지하면서 변조 신호의 크기에 비례하여 주파수가 변하는 방식이다.




그림 2-10. AM 신호 변조 예시

그림 2-10 에서 AM 신호 변조의 예를 확인할 수 있다. 복조 과정은 변조와 반대 순서로 진행되어 원래의 전기 신호를 복원한다. 이러한 변조 및 복조 기술은 주로 오디오 무선 통신 시스템의 성능과 효율성을 향상시키는 데 중요한 역할을 하고있다.

## 2.4. 딥러닝

딥러닝(Deep Learning)은 인공 신경망(Artificial Neural Networks)을 기반으로 하는 기계 학습(Machine Learning)의 한 분야이다. 큰 데이터셋에서 복잡한 패턴을 학습하기 위해 여러 계층으로 구성된 신경망을 사용한다. 이러한 계층 구조는 모델의 학습 능력을 향상시키며, 컴퓨터 비전, 자연어 처리, 음성 인식, 의료 진단, 게임 등

여러 산업 응용 분야에서 활용되고 있다. 딥러닝 알고리즘은 인간의 두뇌 구조에 영감을 받은 인공신경망(ANN)을 사용하여 데이터를 처리하고, 학습을 통해 성능을 개선하는 방식으로 작동한다.

본 연구에서는 DeconvNet, 양방향 LSTM 을 활용한 상상블 모델, 이진 분류, 과적합 방지 기법 등 검증된 딥러닝 기술을 기반으로 음향방출 임펄스 신호 검출 모델을 개발하였다.

### 2.4.1. DeconvNet

DeconvNet(Deconvolutional Network)은 Convolution network 와 Deconvolution network, 두 파트가 대칭적으로 구성되어 있다[7]. 기존의 FCN 기반의 모델이 가진 한계를 개선하기 위해 제안되었다.




그림 2-11. DeconvNet 모델 구조  
출처 : [7]에서 발췌

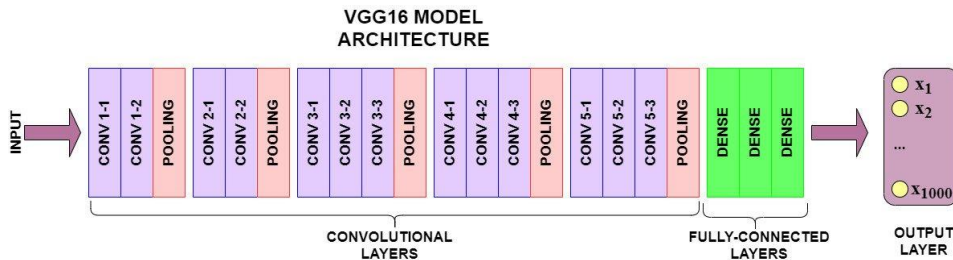


그림 2-12. VGG-16 모델 구조  
출처 : [8]에서 발췌

Convolution network 는 입력 데이터로부터 특징 추출을 수행하며, FCN(Fully Convolutional Networks)으로 구성된 VGG-16 모델에서 마지막 Classification layer 를 제거한 형태이다. Deconvolution network 는 Convolution 이 추출한 특징에서 객체 분할을 수행하며, Deconvolution 과 Unpooling, 두가지 과정으로 구성된다.




그림 2-12. Unpooling, Deconvolution 연산 추상도  
출처 : [7]에서 발췌

그림 2-13 에서 확인할 수 있듯이 Deconvolution 은 Transposed convolution 연산을 수행하며, Unpooling 은 Pooling 의 반대되는 연산을 수행한다. Pooling 과정에서 인덱스 부분을 기록해두고 Unpooling 과정에서 정보 복원에 사용한다. 이러한 과정을 통해 깊어진 네트워크에 따른 정보의 손실을 최소화할 수 있다.

기존의 FCN 기반 모델은 Convolution 및 Pooling 을 통해서 특징을 추출하지만 이렇게 추출된 특징맵은 해상도가 줄어들어 정보의 손실을 야기한다는 한계점이 있다. 이를 채워주기 위해 DeconvNet 모델은 Convolution network 에 이어서 Deconvolution 및 Unpooling 을 수행하는 Deconvolution network 구조를 추가하여 희미해진 특징맵의 해상도를 복원하도록 설계되었다.

## 2.4.2. 양방향 LSTM

양방향 LSTM(Bidirectional Long Short-Term Memory) 은 시계열 데이터 처리에 효과적인 딥러닝 모델 중 하나이다. 일반적인 LSTM 모델은 입력, 출력, 삭제 게이트를 통해 제어되는 단일 셀에 시계열 개념이 추가된 것으로, 과거의 정보를 기억할 수 있도록 설계되었다. 하지만 입력 데이터를 순차적으로 처리하기에 단방향 패턴을 기반으로만 출력이 계산되는 한계가 있다. 이러한 문제를 해결하기 위해 제안된 양방향 LSTM 은 두개의 개별 LSTM 아키텍처를 서로 연결하여 사용하는 구조를 갖고있다[9].

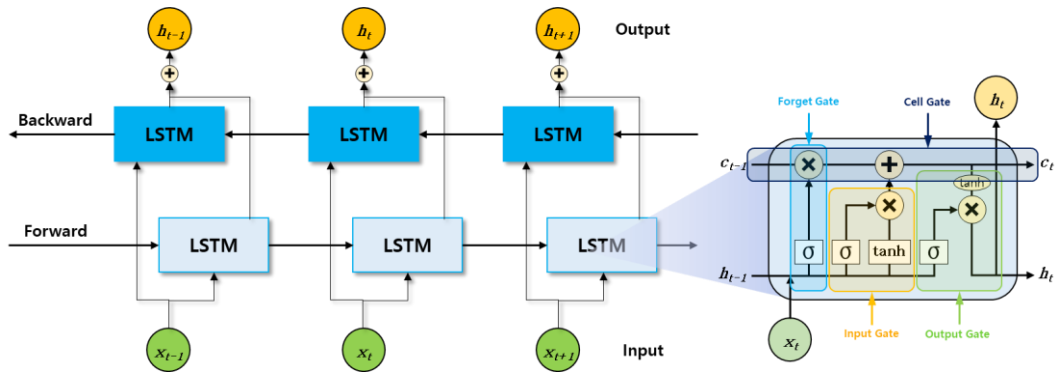


그림 2-14. 양방향 LSTM 모델 구조

그림 2-14의 구조를 살펴보면 순방향으로 학습하는 기존의 LSTM에 역방향으로 학습할 수 있는 LSTM을 추가해 양방향으로 학습할 수 있도록 유도하여 시퀀스 특징의 앞과 뒤에 대한 구분없이 의미적인 정보를 복합적으로 반영하고 이해할 수 있도록 설계되었다. 추가된 역방향 레이어를 통해 단일 LSTM 모델보다 시퀀스 예측 작업에서 일반적으로 더 나은 성능을 얻을 수 있다.

양방향 LSTM은 음성 인식, 자연어 처리, 시계열 예측 등 다양한 분야에서 활용되고 있으며, 다른 딥러닝 모델과 함께 사용되기도 한다.

### 3. 음향방출 임펄스 신호 검출

#### 3.1. 합성신호 데이터 생성 알고리즘

음향방출 센서에 의해 수집되는 신호는 다수의 임펄스 신호를 포함하고 있다. 에너지의 빠른 방출로 인해 발생하는 응력파가 구조물의 표면을 따라 배경 소음과 함께 신호의 형태로 전달된다. 응력파의 강도, 구조물의 재질, 외부 소음 등 여러 환경 요인에 따라 임펄스 신호의 특성과 파형이 달라질 수 있다. 딥러닝 방법을 이용하여 임펄스 신호를 검출하기 위해서는 신호의 지속 시간, 과도 및 감쇄 시간을 포함하여 여러 형태의 특징을 지닌 임펄스 신호 데이터를 보유하는 것이 필수적이다. 이는 다양한 환경 조건에서 데이터를 수집하거나 이를 광범위하게 모사할 수 있는 테스트베드를 구축해야만 달성할 수 있다는 어려움이 따른다. 그 외에도 수집된 데이터로부터 임펄스 신호를 순수 레이블링 해주는 작업은 현실적으로 많은 시간과 비용이 들어간다. 따라서 다양한 환경 조건과 상황에서 수집된 음향방출 신호와 유사한 합성신호를 시뮬레이션 하는 기술이 필요하다. 합성신호 데이터 생성 알고리즘은 크게 임펄스 변조 신호 생성 과정과 신호 합성 과정으로 구분할 수 있으며, 이를 이용해 본 연구가 중점적으로 목표하는 “딥러닝 기반 임펄스 신호 검출 모델”을 구현하는 과정에서 필요한 학습 데이터를 다량 확보하고자 한다.




그림 3-1. 이중 지수 함수 그래프,  $\alpha = 0.7$ ,  $\beta = 0.2$ ,  $d = 50$

먼저, 임펄스 변조 신호는 이중 지수 함수 기반으로 나타낼 수 있다. 하나는 진폭의 과도 현상을, 다른 하나는 진폭 감쇄 현상을 표현하는 함수로 구성된다. 임펄스 변조 신호 생성 함수는 (7)로 정의된다.

$$m(t) = (1 - e^{-\alpha t}) e^{-\beta t}, \quad 0 \leq \alpha < 1, \quad 0 \leq \beta < 1, \quad 0 \leq t < d, \quad (7)$$

여기서  $\alpha$ 는 진폭의 과도 계수,  $\beta$ 는 감쇄 계수,  $d$ 는 신호의 길이(샘플 수)를 가리킨다. 그림 3-1 은  $\alpha = 0.7$ ,  $\beta = 0.2$ ,  $d = 50$  에 대한 함수의 그래프이다. 임펄스 신호는 짧은 시간 내에 발생한 응력과 에너지가 급격하게 전달되는 형태이기에 일반적으로

그림 3-1 처럼 시간상에서 진폭이 빠르게 과도한 다음, 점차 감쇄하는 돌발형 신호의 파형을 보인다. 임펄스 신호를 묘사하기 위해 먼저 변조 신호를 생성해야 한다. 변조 신호에서 과도, 감쇄 계수를 임의로 조정하여 신호 특징을 지닌 변조 신호를 생성할 수 있다. 이렇게 생성된 변조 신호는 시간과형(시간상에서 에너지 변화)을 의미한다.

임펄스 신호는 에너지가 감쇄됨에 따라 국부적인 시간동안 지속되어야 한다. 즉, 생성된 변조 신호가 임펄스 신호 합성에 활용되기 위해서는 명확한 신호 길이가 정의되어야 한다. 하지만 감쇄 지수 함수는 진폭이 무한히 0 으로 수렴하지 않기 때문에 신호의 길이가 정의될 수 없다. 임펄스 신호는 국부적인 시간 내에서 에너지 분포에 대한 변화를 나타내기 때문에 분포 통계치를 기반으로 한 Tukey 경계선[6]을 사용해서 신호의 길이를 정의하였다. Tukey 기준은 일반적으로 이상치 검출의 임계치로 활용되고 있으나 본 연구에서는 변조 신호의 길이를 정의하기 위해 사용되었다. 이는 변조 신호 생성시 정의된 감쇄 지수 함수에서 Tukey 경계선을 초과한 시퀀스(이상치 값)는 감쇄가 충분히 완료된 시점으로 분류하고 신호 변조에 사용하지 않도록 하기 위함이다. 변조 신호의 길이  $d$ 를 구하는 함수는 신호의 감쇄 계수와 Tukey 기준에 의해 방정식 (8)로 정의할 수 있다.

$$d = \frac{\ln 4}{\beta} + 1.5 \frac{\ln 3}{\beta}, \quad 0 \leq \beta < 1, \quad (8)$$

그림 3-2 에서 보여지는 것처럼 지수 분포에서의 Tukey 기준  $Q3 + 1.5(Q3 - Q1)$ 을 간단히 한 형태의 방정식이며, 여기서  $\beta$ 는 신호의 감쇄율을 가리킨다.

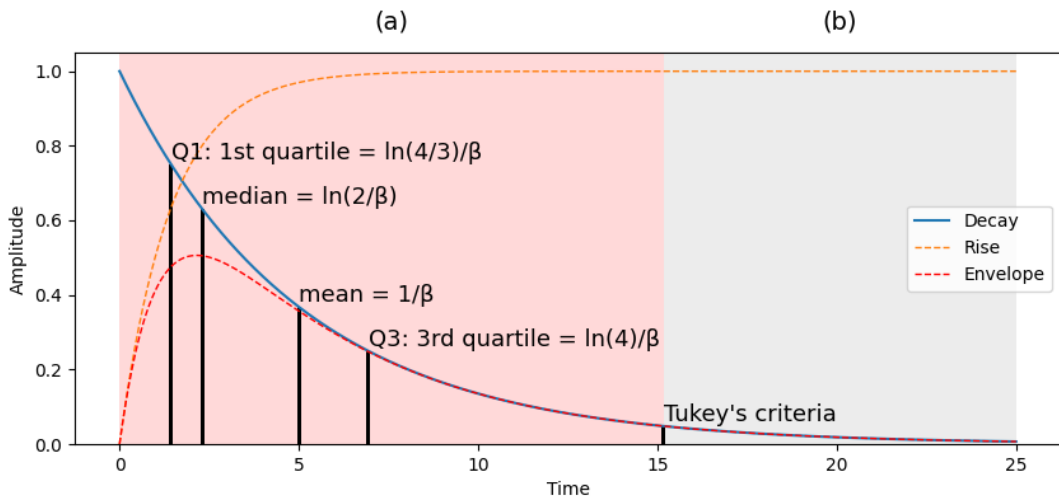


그림 3-2. (a) 변조 신호 값, (b) 이상치 값, 지수 함수에서의 Tukey 기준

음향방출 신호는 일련의 정현파, 임펄스 신호, 배경 노이즈 등으로 구성된다. 앞선 과정을 통해 변조 신호를 생성하고 나면, 이를 합성할 대상이 되는 캐리어 신호가 필요하다. 합성 신호에서 임펄스 신호가 매질을 따라 전파되는 과정을 표현하기 위해 기본이 되는 신호이며, 이는 음향방출 신호에서 일련의 정현파와 배경 노이즈를 지닌

신호의 역할을 한다. 센서의 종류에 따라 측정 가능한 신호의 주파수 범위가 광범위하며 산업 환경에서 무작위로 발생하는 노이즈 또한 다양하기에, 이상적인 신호의 주파수 대역을 특정하기는 어렵다. 딥러닝 모델을 이용해 다양한 환경 조건에서 임펄스를 검출하기 위해서는 학습 데이터를 일반화할 필요가 있다. 따라서, 신호의 주파수 대역을 특정하는 대신, 일반적인 잡음을 나타내며 정규분포를 따르는 가우시안 노이즈로 캐리어 신호를 생성하였다.

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad (9)$$

정규분포의 확률밀도 함수이며, 여기서  $\mu$ 는 평균,  $\sigma$ 는 표준편차, 표준 편차의 제곱인  $\sigma^2$ 을 분산이라고 가리킨다. 이 함수는 평균에서 최고점을 가지며 분산과 표준 편차는 비례 관계를 가진다.

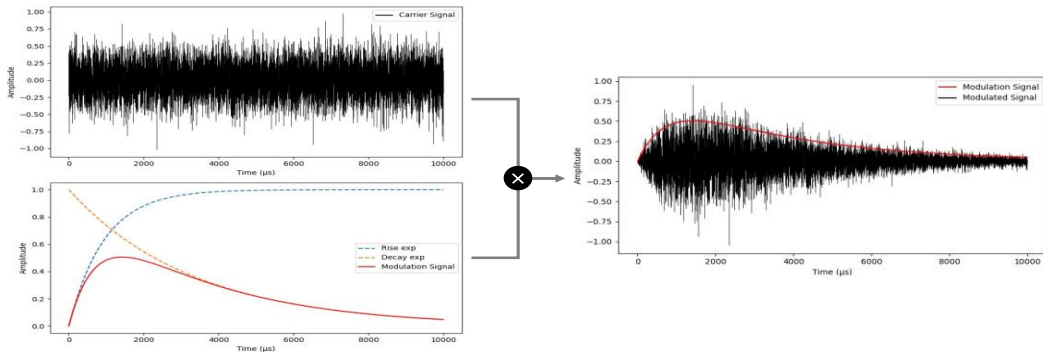


그림 3-3. 임펄스 신호 변조 개념도

그림 3-3 은 캐리어 신호와 변조 신호를 이용해 생성한 음향방출 합성 신호 데이터를 시각화한 그래프이다. 단일 변조신호에 대한 신호 변조 함수는 AM 변조를 활용하였으며 (10)으로 정의된다.

$$s(t) = \begin{cases} (1 + km_{t-i})c_t, & 0 < k, 0 < i \leq t < i + d, \\ c_t, & otherwise, \end{cases} \quad (10)$$

여기에서  $c$ 는 캐리어 신호,  $m$ 은 변조 신호,  $k$ 는 변조 진폭 감도,  $d$ 는 변조 신호의 길이(샘플 수),  $i$ 는 임펄스 발생 시점을 가리킨다. 변조 신호  $m$ 은 임펄스 변조 신호 생성 함수 (7)을 통해  $0 \leq \alpha < 1$ ,  $0 \leq \beta < 1$  변수 범위 내에서 다양하게 생성되며, 캐리어 신호  $c$ 는  $\mu = 0$ ,  $\sigma = 1$ , 정규분포 확률밀도함수 (9)에 따르는 무작위 값들로 생성한다.

$$y(t) = \begin{cases} 1, & 0 < k, 0 < i \leq t < i + d, \\ 0, & otherwise, \end{cases} \quad (11)$$

학습에 필요한 레이블링 데이터 또한, 레이블링 함수 (11)와 같이 단일 임펄스가 위치한 시간 인덱스를 1(임펄스), 나머지를 0(노이즈)으로 레이블링한다.

### 3.2. 임펄스 신호 검출 모델

제안된 딥러닝 기반 임펄스 신호 검출 모델의 기본적인 구조는 그림 3-4 와 같다.

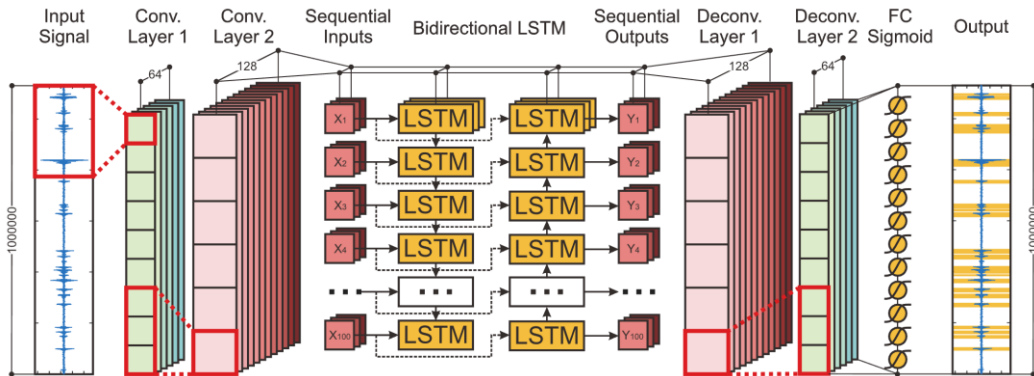


그림 3-4. 제안 모델의 구조

모델에서 요구되는 입력데이터는 특징 추출이 진행되지 않은 Raw 음향방출 신호이고, 모델의 출력 값은 일련의 임펄스 예측 확률 값. 즉, 입력 신호 시퀀스에 대응하는 0~1 사이의 확률 값을 가지는 시퀀스이다. 모델의 입출력 모형은 그림 3-5 와 같다.




그림 3-5. 제안 모델의 입출력 모형

그림 3-5 에 따르면, 본 모델은 순차적인 데이터를 입력으로 받아 순차적인 데이터를 출력하는 Seq2Seq 모델로 정의될 수 있다. 이러한 Seq2Seq 생성 모델의 주요 구성



요소로는 인코더-디코더 구조가 사용되었다. 인코더와 디코더의 기본적인 구조는 합성곱(Convolution)과 역합성곱(Deconvolution)으로 이루어진 ConvNet 구조를 참조하여 설계하였다.

인코더의 마지막 레이어는 양방향 LSTM(Bidirectional LSTM)을 사용하여, 시퀀스를 양쪽 방향에서 정보를 인코딩할 수 있도록 하였고, 디코더의 마지막 레이어는 시그모이드(Sigmoid) 활성화 함수를 갖는 완전 연결 계층(Fully Connected Layer)으로 구성하였다. 이를 통해 출력에서 각 시퀀스에 대한 임펄스 확률 분포를 얻을 수 있다.

모델의 출력을 통해 얻은 시퀀스는 0~1 범위 내의 확률 분포 값을 가지므로 각 시퀀스 값을 통해 임펄스 유무를 판단하기 위해서, 최종적으로 0.5의 임계 값을 기준으로 반올림하도록 분류 작업이 필요하다. 이러한 후처리 작업을 통해 분류된 결과는 1(임펄스) 또는 0(노이즈), 두 개의 클래스를 가지며 그림 3-6에서 예를 확인할 수 있다.




그림 3-6. 출력 값 후처리를 통한 분류 결과

학습 과정에서 모델의 과적합을 방지하기 위한 전략으로, 드롭아웃(Dropout) 및 배치 정규화(Batch Normalization) 레이어가 각 층 사이에 적용되었다. 이러한 기법은 모델을 일반화하고 성능을 향상시키는 데 도움이 된다. 제안된 기본 모델 구조에 이러한 기법들을 적용하였고, 실험을 위해 사용된 최종적인 모델은 그림 3-7과 같은 그래프를 갖는다.

제안된 모델의 구조를 구현하고 실험하기 위해 사용된 워크스테이션은 16 코어 2.10 GHz CPU, 32 GB RAM 메모리, Nvidia Titan RTX 외장 그래픽 3개로 이루어진 하드웨어 구성과 Ubuntu 18.04 운영체제로 구성되었다. 워크스테이션 내 Python 3.7 가상환경을 구축하고 딥러닝 오픈소스 라이브러리인 Tensorflow 2.3.0을 설치하여 실험을 진행하였다.

합성신호 생성 과정을 통해 1000 개의 신호를 생성하여 학습에 사용하였다. 1000 개의 신호중 50%는 학습에, 50%는 검증에 활용하였다. 단일 합성신호를 생성하는 일련의 과정은 그림 3-8 과 같이 3 단계로 구성된다.

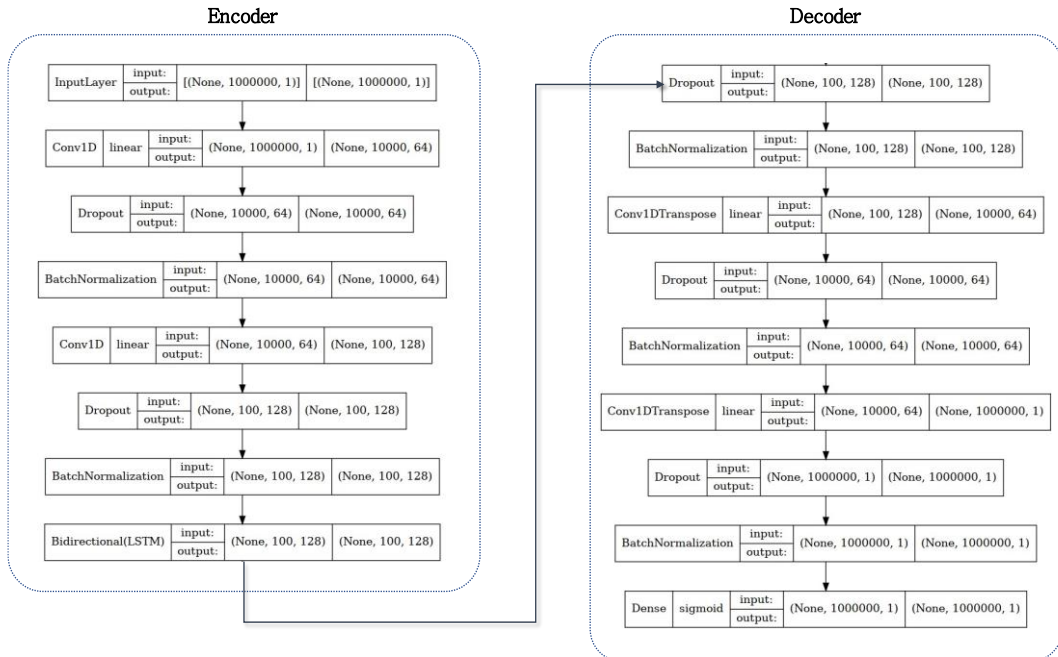


그림 3-7. 실험에 사용된 모델의 그래프

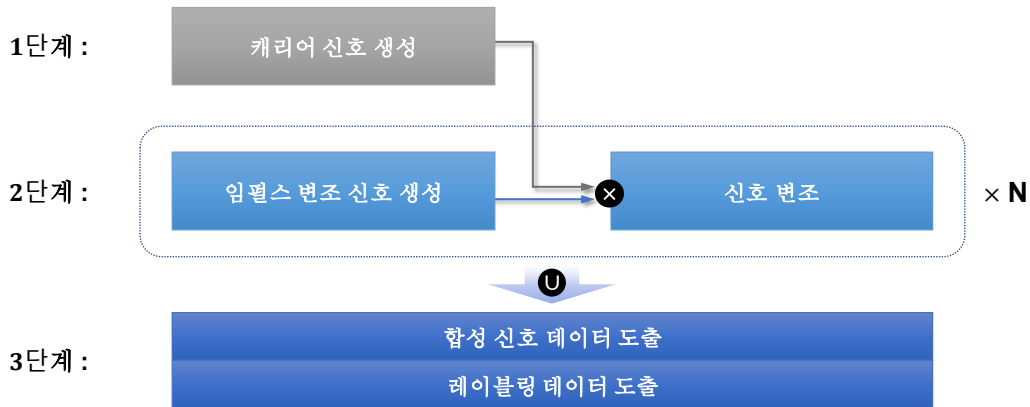


그림 3-8. 학습 데이터 생성 프로세스

1 단계에서는 정규분포 확률밀도함수 (9)에 따르는 무작위 값들로 캐리어 신호를 생성하였다. 2 단계에서는 함수 (7)을 이용해 임펄스 변조 신호를 생성하고 함수 (10)를 이용해 캐리어 신호와 합성하였다. 이 때, 0~10 사이의 무작위 값, N 을 선정하고 2 단계 과정을 N 번 반복하였다. 결과적으로 3 단계에서는 그림 3-9 와 같이 N 개의 임펄스 신호가 변조된 합성신호가 도출되며, 함수 (11)를 통해 레이블링

데이터까지 도출하였다. 이때, 학습 데이터를 일반화하기 위해서 함수 (7), (9), (10), (11)에 요구되는 매개변수를 표 3-1에 명시된 수 범위 내에서 함수가 사용될 때마다 무작위로 선별하였다. 또한, 각 합성신호에 사용된 캐리어 신호  $c$ 의 길이는 1MHz로 설정하였다.

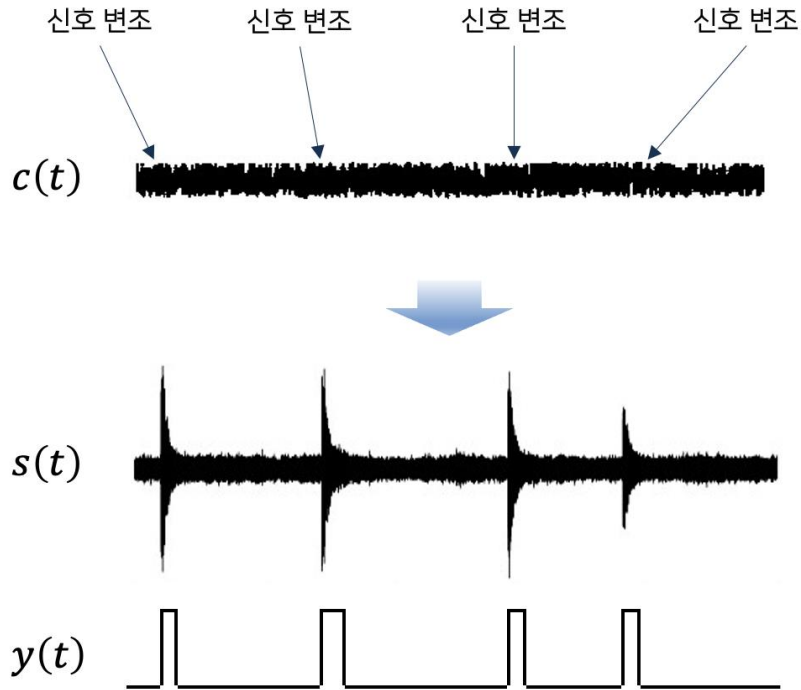


그림 3-9. 학습 데이터 생성 결과 예시

표 3-1. 학습 데이터 생성에 사용된 매개변수 범위

함수	매개변수	범위
(7) 임펄스 변조 신호 생성 함수	$\alpha$	0 ~ 1 실수
	$\beta$	0 ~ 1 실수
	$d$	Tukey's criteria
(9) 정규분포 확률밀도 함수	$\mu$	0
	$\sigma$	1
(10) 신호 변조 함수	$k$	0 ~ 100 정수
(11) 레이블링 함수	$i$	0 ~ 1,000,000 정수

### 3.3. 검출 모델 학습 결과

음향방출 합성신호 데이터를 바탕으로 딥러닝 모델을 학습시켰다. 학습에 사용된 1000개의 데이터는 10개씩 나누어 총 100번의 배치로, 매 배치마다 10 Epoch 학습을 진행하였다. 제안된 딥러닝 모델은 확률 값을 출력 값으로 가지는 이진 분류

모델이므로 Binary Cross Entropy 손실 함수 (12)을 통해 Loss 를 계산하고, Adam 최적화 함수 (13)을 사용해 모델의 가중치를 최적화하도록 학습을 진행하였다.

$$BCE(\hat{y}, y) = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (12)$$

$$\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (13)$$

무작위로 생성된 음향방출 합성신호 데이터를 바탕으로 모델을 학습시킨 결과, 다양한 형태를 가진 음향방출 임펄스 신호를 검출하는 방법을 학습할 수 있었다. 그림 3-10 을 통해 일부 검증 데이터로부터 임펄스 신호를 검출한 결과를 시각적으로 확인할 수 있다.

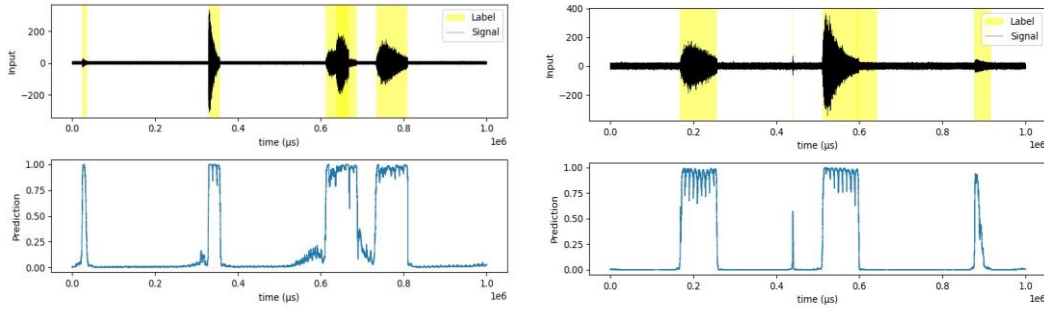


그림 3-10. 검증 데이터의 임펄스 검출 결과

학습된 딥러닝 모델의 성능 평가를 위해 Precision, Recall, F1-Score 등의 성능 지표가 활용되었다.

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Recall = \frac{TP}{TP + FN} \quad (15)$$

$$F1\ Score = \frac{2(Recall \times Precision)}{Recall + Precision} \quad (16)$$

여기에서  $TP$ (True Positive)는 임펄스를 임펄스로 올바르게 분류한 시간 인덱스의 수,  $FN$ (False Negative)은 노이즈를 노이즈가 아니라고 잘못 분류한 시간 인덱스의 수,  $FP$ (False Positive)는 노이즈를 노이즈로 올바르게 분류한 시간 인덱스의 수를 가리킨다.




그림 3-11. 학습 배치에 따른 성능 곡선

그림 3-11 은 학습 배치에 따른 성능 곡선이다. 실험을 통해 Epoch 에 따라 성능이 향상되는 모습을 확인할 수 있으나, 약 300 Epoch 부터는 Accuracy, Precision, Recall, F1-Score 등 각 성능 지표에서 값이 크게 변동하지 않는다는 결과를 도출하였다. 따라서 300 Epoch 을 성능 한계점으로 정하고 학습을 중단하였다. 300 Epoch 에서 각 성능 지표에 대한 수렴 값은 표 3-2 와 같다.

표 3-2. 학습 결과 성능 지표

No	지표	수렴 값
1	Loss	0.2302
2	Accuracy (%)	92.06
3	Precision (%)	90.69
4	Recall (%)	71.93
5	F1 score (%)	80.23

### 3.4. 실제 구조물 검사 적용성 평가

제안된 딥러닝 기반 음향방출 임펄스 신호 검출 방법의 실제 구조물 검사에 대한 적용 가능성을 평가하였다. 이를 위해, 실제 배관에서 발생하는 음향방출 신호를 수집하고, 학습된 딥러닝 모델을 이용해 임펄스 신호를 검출하였다. 검출된 결과를 배관 검사 기술에 도입하여 기존의 검출 방법과 비교하고, 검사 성능과 효율성을 검토하였다.




그림 3-12. 산업용 배관 테스트베드 현장

평가에 활용된 데이터는 그림 3-12 에 표시된 실제 산업용 수도 배관으로부터 취득되었으며 배관의 도면은 그림 3-13 과 같다. 각 치수를 포함하여 실험에 사용된 테스트베드 배관의 규격은 표 3-3 을 따른다.




그림 3-13. 산업용 배관 테스트베드 도면

표 3-3 실험에 사용된 테스트베드 매개변수

No	매개변수	치수/정보
1	AE 센서 1 위치	2600 mm
2	AE 센서 2 위치	100 mm
3	누수 위치	900 mm

4	배관 두께	6.02 mm
5	배관 직경	114.3 mm
6	배관 재질	Stainless steel 304
7	데이터 수집 샘플링율	1,000,000 Hz

데이터 수집 절차는 그림 3-14 와 같이 진행되었다. Analog-to-digital(ADC) 변환 모듈과 데이터 기록 프로그램을 사용하여 데이터를 수집하고 저장하는 과정은 4 단계로 구성된다.

- 1 단계: 음향방출 센서를 통해 음향방출 파동을 아날로그 신호로 변환
- 2 단계: 아날로그 신호를 ADC 변환 모듈을 통해 디지털 신호로 변환
- 3 단계: ADC-PC 통신 인터페이스를 통해 수집 데이터 수신
- 4 단계: 데이터 기록 프로그램을 통해 수집 데이터를 저장장치에 저장




그림 3-14. 데이터 수집 시스템 구성도




그림 3-15. 테스트베드 데이터 수집 절차

데이터 수집을 위해 사용된 음향방출 센서는 MITRAS 사에서 생산된 R15I-AST 고감도 음향방출 센서이다. ADC 변환 모듈은 NI(National Instruments) 사에서 생산된 NI-9223 모듈을 사용하였으며, 표준 고속 범용 직렬 버스(USB)를 통해 통신이 가능한 프로토콜 및 인터페이스를 내장하고 있다. 음향방출 센서는 표 3-3 에 명시된 매개변수에 따라 해당하는 위치에 테이핑하여 배관 표면에 고정하였고 센서와



배관 표면의 접촉을 향상시키기 위해 특수 젤을 함께 사용하였다. 데이터 수집시 NI사에서 제공하는 Python 인터페이스 라이브러리와 함께 자체 개발한 데이터 기록 소프트웨어를 사용하였다.

데이터는 기온 약 26°C, 수압 7 bar, 13 bar, 18 bar 의 제어 환경에서 수집되었다. 그림 3-15 는 이를  $P_1$ (7 bar),  $P_2$ (13 bar),  $P_3$ (18 bar)으로 표현하여 수집 절차를 기록한 그래프이다. 펌프를 통해 테스트베드 배관의 압력을  $P_1$  까지 끌어올린 뒤, 4 가지 누수 크기(핀홀 크기 0.3mm, 0.5mm, 1mm, 2mm)에 대해서 1MHz 샘플링율로 2 분동안 기록하였다. 해당 과정을  $P_2$ ,  $P_3$  제어 환경에서도 순차적으로 적용하여 데이터를 수집하였다.

수집된 실제 데이터로부터 임펄스 신호를 수작업으로 레이블링하는 것은 현실적으로 많은 시간과 비용이 요구되기 때문에, 임펄스 검출 성능을 직접적으로 평가하는 것이 어렵다. 이에 따라, 본 연구에서 제안된 딥러닝 기반 임펄스 검출 모델과 T.B. Quy 에 의해 제시된 ABM 기반 적응형 임펄스 검출 모델[4]을 각각 사용하여 임펄스 신호를 검출하였다. 그리고, ABM 기반 방법에서 활용된 누출 위치 추정 기술[4]을 두 검출 결과에 동일하게 적용하여 위치 추정 성능을 통한 임펄스 검출 성능을 간접적으로 비교하였다. 이를 통해 배관 검사와 같은 응용 기술에서 범용적으로 적용 가능한지를 검증하고자 하였다.

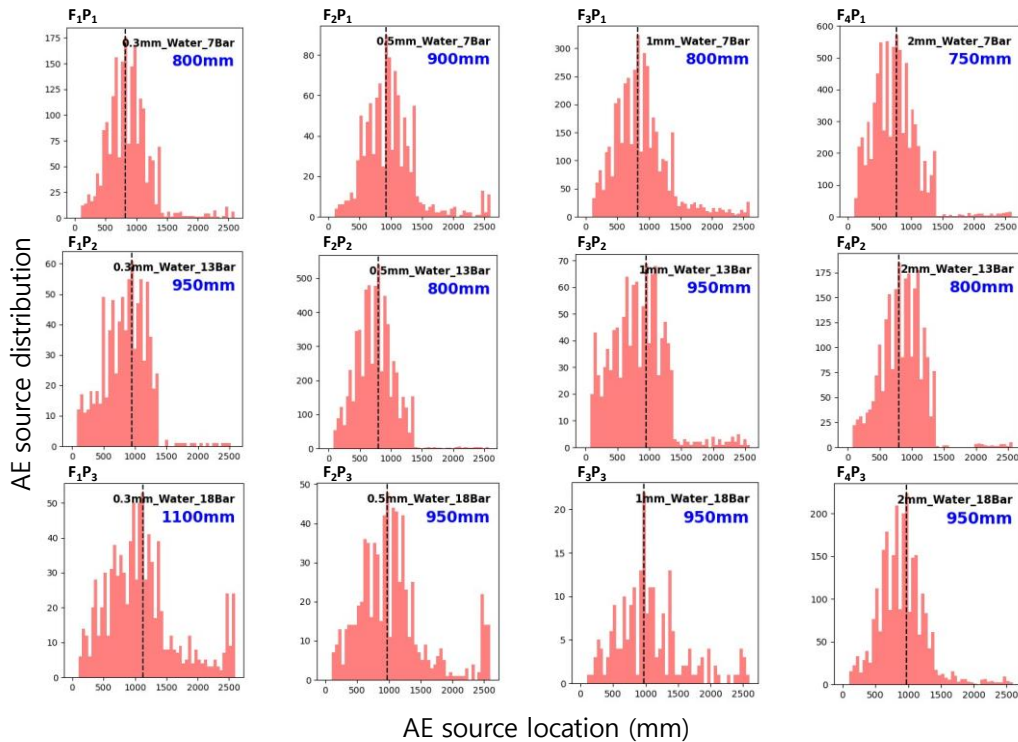


그림 3-16. 누수 위치 추정 분포도



표 3-4 누수 위치 추정 결과 비교표

		Method		
		ABM	Proposed	
Dataset	F <sub>1</sub> P <sub>1</sub>	800; 4	800; 4	
	F <sub>2</sub> P <sub>1</sub>	850; 2	900; 0	
	F <sub>3</sub> P <sub>1</sub>	900; 0	800; 4	
	F <sub>4</sub> P <sub>1</sub>	950; 2	750; 6	
	F <sub>1</sub> P <sub>2</sub>	800; 4	950; 2	
	F <sub>2</sub> P <sub>2</sub>	800; 4	800; 4	
	F <sub>3</sub> P <sub>2</sub>	850; 2	950; 2	
	F <sub>4</sub> P <sub>2</sub>	800; 4	800; 4	
	F <sub>1</sub> P <sub>3</sub>	850; 2	1100; 8	
	F <sub>2</sub> P <sub>3</sub>	800; 4	950; 2	
	F <sub>3</sub> P <sub>3</sub>	850; 2	950; 2	
	F <sub>4</sub> P <sub>3</sub>	900; 0	950; 2	
	Average		845.8; 2.5	891.7; 3

누수 위치 [mm], 오차율 [%]

테스트베드 배관의 누수 위치 추정의 결과에 대한 검출 위치 분포도는 그림 3-16 과 같으며, ABM 기반 모델과의 결과 비교표는 표 3-4 와 같다. 실험 결과, 제안된 모델은 ABM 모델보다 평균적으로 더 정확한 누수 위치 추정 값을 보이지만, 평균 오차율은 조금 더 높게 나왔다. 결론적으로, 배관 검사에서 ABM 모델에 비해 양호한 성능을 보이며, 배관 누수 위치 추정 기술을 통해 딥러닝 기반 음향방출 임펄스 신호 검출 방법이 실제 구조물 검사에 적용 가능성을 확인하였다.

## 4. 적용 시스템

### 4.1. 지하배관 상태 모니터링 시스템

전국 국가산업단지, 도시, 주거 및 상업지역 등에 매설된 지하배관의 노후화로 인해 경쟁력 저하 및 파손, 누출 사고와 같은 재난 발생이 지속적으로 발생하고 있다. 따라서, IoT, 빅데이터, 인공지능 등의 기술을 융복합 활용하여 노후화된 지하매설배관 인프라의 안전관리 방안 수립에 기여하고자 지하배관 상태 모니터링 시스템을 구축하였다.

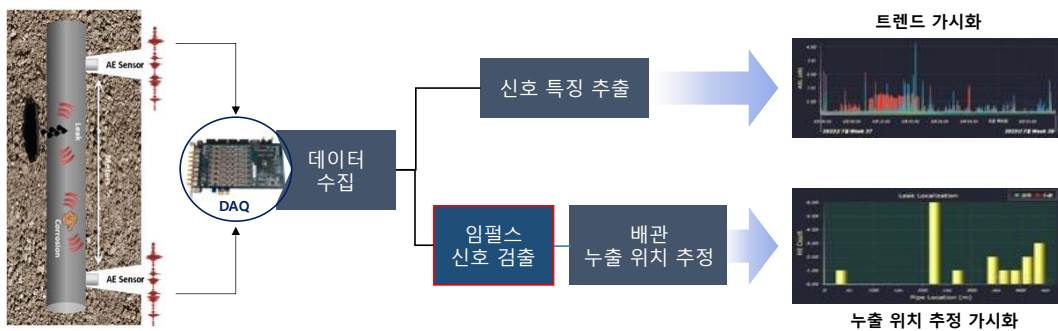


그림 4-1. 지하배관 상태 모니터링 시스템 구성도

본 시스템에서는 앞서 제안된 임펄스 검출 기술에 기반하여 배관 누수 검출 및 위치 추정을 수행할 수 있는 인터페이스가 포함되었으며 그 외에도 진동, 온도 등의 다중 센서 데이터를 기반으로 트렌드 분석이 가능하도록 웹 기반 인터페이스를 개발하였다.

표 4-1. 지하배관 상태 모니터링 서버 규격

구분	세부 규격	수량
운영체제	Ubuntu 18.04	1 식
프로세서	Intel Xeon Silver 4110 CPU @ 2.10GHz	
메모리	64.0 GB (RAM)	
스토리지	10TB	

표 4-2. 지하배관 상태 모니터링 시스템 개발 환경

구분	세부 규격
서버 프레임워크	NestJS 7.6
UI 프레임워크	Vue 2.6, Bootstrap 5
데이터베이스	MySQL 8.0

지하배관 상태 모니터링 시스템은 표 4-1 에 명시된 스펙의 서버 환경에서 구축하였으며 개발 프레임워크 및 데이터베이스 등 개발 환경은 표 4-2 의 구성표와 같이 선정하여 웹 기반 어플리케이션 개발을 목표로하였다.



그림 4-2. 지하배관 상태 모니터링 메인 화면

- (a). 지하배관, 센서 목록 조회 및 선택 기능
- (b). 진단, 분석 도구 선택 패널
- (c). 배관 도면 종류 선택 패널
- (d). 배관 도면 조회 패널
- (e). 센서 데이터 추이 그래프
- (f). 알람 조회 패널

먼저, 지하배관 상태 모니터링 시스템의 메인 화면은 그림 4-2 와 같이 6 개의 항목으로 구성하였다. 패널 (a)에서 트리 형태로 지하배관과 설치된 센서 목록을 조회할 수 있으며 단일 선택하여 해당 배관에 대한 상태 모니터링이 가능하다. 패널 (b)를 통해 “지하배관 상태 진단”, “규칙 기반 진단” 등의 분석 도구를 선택할 수 있다. 패널 (c)에서 배관의 도면/실사 보기 모드를 전환할 수 있다. 패널 (d)에서는 패널 (c)를 통해 선택한 종류의 도면을 출력하고, 도면상에서 센서 설치 위치, 전원 관넬 설치 위치 등 현장 시스템의 전반적인 현황을 파악할 수 있도록 구성하였다. 그래프 (e)에서는 센서로부터 수집되는 데이터에 대해 실시간으로 특징 추이를 확인할 수 있다. 마지막으로, 우측 “Alarm List” 사이드 메뉴를 클릭 시 패널 (f)가 팝업되며, 최근 발생한 알람 현황을 확인할 수 있다. 여기서 알람 기준은 국제표준화 기구(ISO)에서 제시하는 ISO 10816 진동 평가 기준, 미국비파괴검사협회(ASNT)에서 제시하는 음향방출 평가 기준이 활용되었다.

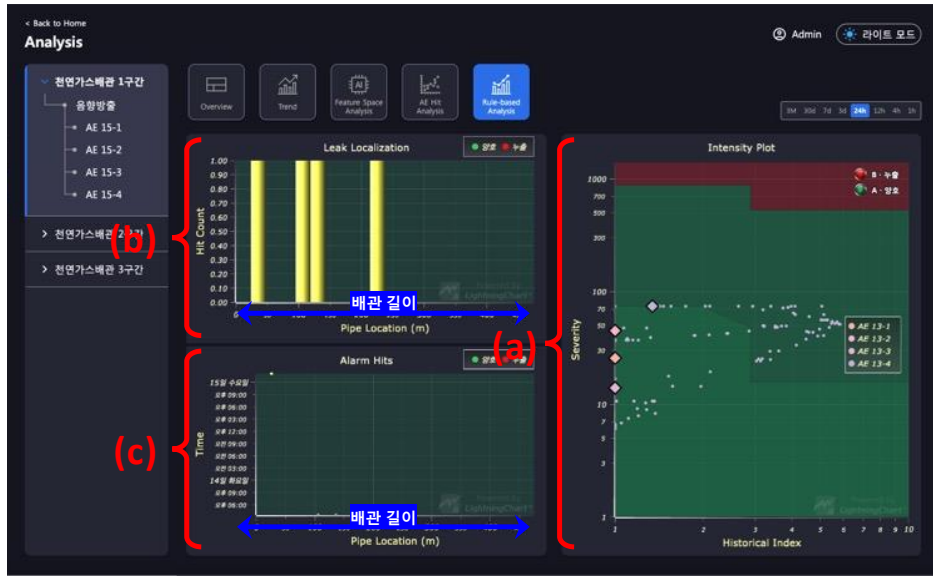


그림 4-3. 지하배관 규칙 기반 진단 도구 화면

- (a). Intensity 규칙 기반 그래프
- (b). 누수 위치 추정 산포도 그래프
- (c). 누수 위치 추정 타임라인 그래프

다음으로, 지하배관 규칙 기반 진단 도구의 화면은 그림 4-3 과 같이 3 개의 그래프로 구성되어 있다. 해당 그래프들은 제안된 임펄스 검출 모델을 이용하여 검출된 임펄스 신호에 기반해 진단 결과를 시각화한 그래프이다. 그래프 (a)는 수집된 음향방출 신호로부터 임펄스 신호를 검출하여 특징 데이터를 추출하고 2 차원 규칙 기반 평면상에서 진단할 수 있도록 한 것이다. 여기에서 X 축에 대한 특징은 Historical Index 이며, Y 축에 대한 특징은 Severity 이다. 그래프 (b)는 검출된 음향방출 임펄스 신호에 기반하여 추정된 “누출원 위치(X)”와 “누출 크기(Y)”를 히스토그램 형태로 시각화한 것이다. 그래프 (c)는 검출된 음향방출 임펄스 신호에 기반하여 추정된 “누출원 위치(X)”와 “누출 시점(Y)”을 타임라인 형태로 시각화한 것이다.

## 5. 결론

본 연구는 지하 시설 구조물의 안전성과 지속성을 확보하기 위해 음향방출 검사 기술 발전에 기여하는 딥러닝 기반 음향방출 임펄스 신호 검출 방법을 개발하는 것을 목표로 하였다. 먼저, 음향방출 합성신호 데이터를 생성하는 모델을 개발하여 다양한 환경 조건을 모사한 합성신호 데이터를 생성하여 연구에 필요한 데이터를 풍부하게 확보할 수 있었다. 생성된 데이터를 토대로 제안된 딥러닝 기반 임펄스 신호 검출 모델을 학습시켰고 모델의 정확도는 약 92%로 수렴하였다. 학습된 모델을 이용해 검출된 결과를 배관 누출 위치 추정 검사 기술에 적용해본 결과, 적응형 임계치 기반 모델인 ABM 모델에 비해 평균적으로 준수한 검사 성능을 보여주었다. 제안된 딥러닝 기반 임펄스 신호 검출 방법은, 실행 환경에서 사용자 경험에 의한 입력 매개변수가 요구되지 않도록 설계되었으며 환경 요소에 따라 발생하는 여러 잡음에 대응이 가능하다. 또한, Conv 망을 기반한 Encoder-Decoder 딥러닝 구조를 활용하여 모델의 추론 시간을 단축시킬 수 있었다. 이는 기존 검출 방법에서 드러났던 다양한 문제점을 해결함으로써 실제 구조물 검사에서도 효과적으로 적용 가능함을 보여준다. 따라서, 제안된 방법은 구조물의 안전성과 지속성을 향상시키고, 구조물 유지관리와 진단 분야에서 중요한 역할을 하는데 기여하며, 음향방출 검사 분야에서 딥러닝 모델의 활용 가능성을 비추고 미래의 구조물 검사와 관리에 있어 더 효과적인 방법을 제공할 수 있다고 판단된다. 또한, 본 연구에서는 배관을 통해 실효성을 검증하였지만 이외의 다양한 분야에서도 연구 결과가 적용될 수 있으며, 특히 건설, 교량, 항공기, 선박 등의 구조물 진단 및 유지관리에 활용될 수 있다. 이로 인해 사람들의 생명과 재산을 보호하는 데 기여할 것으로 예상되며, 국가 및 산업 안전의 발전에도 긍정적인 영향을 미칠 것으로 기대된다.

향후 연구 방향으로는 다음과 같은 사항들을 고려할 수 있다. 첫째, 수도배관 테스트베드 외에도 다양한 구조물 유형 및 소재에 대한 적용을 검토하여 제안된 방법의 범용성과 실용성을 높일 수 있다. 이를 통해 다양한 상황에서 음향방출 검사 기술의 적용성을 확장할 수 있을 것이다. 둘째, 실시간 검출 시스템 개발을 통해 현장에서의 실용적인 검사 속도를 향상시킬 수 있다. 이를 통해 실시간으로 구조물의 상태를 모니터링하고, 이상 징후를 조기에 발견하여 즉각 대응할 수 있게 되어, 구조물의 안전성을 더욱 향상시킬 수 있다. 셋째, 결함 진단 및 예측 기능 확장을 통해 구조물의 수명을 예측하고 유지관리 계획을 수립하는 데 도움이 될 수 있다. 딥러닝 모델을 활용하여 구조물의 결함 종류와 크기를 정확하게 판별하고, 이를 바탕으로 구조물의 남은 수명을 예측하는 모델을 개발할 수 있다. 이를 통해 구조물의 유지관리 비용을 절감하고, 안전성을 유지할 수 있다. 마지막으로, 딥러닝 기술의 발전과 함께 다양한 음향방출 데이터에 대한 연구를 확장하면, 알고리즘의 정확도와 신뢰성을 높일 수 있다. 더욱 정교한 모델 구조와 알고리즘을 개발하여, 음향방출 검사 기술의 정확도와 효율성을 더욱 높일 수 있다.

결론적으로, 이러한 향후 연구 방향들을 추진함으로써, 본 연구가 제시한 딥러닝 기반 음향방출 임펄스 신호 검출 방법은 구조물 관리와 안전성 확보에 큰 도움이 될 것으로 기대된다.

## 참고 문헌

- [1] 강찬수, "하수관 길이 지구 세 바퀴 반...하지만 40%는 도로 밑 '복병'," vol. Society, ed. Seoul, Korea: JoongAng Ilbo, 2019.
- [2] S. W. Rienstra and A. Hirschberg, "An introduction to acoustics," *Eindhoven University of Technology*, vol. 18, p. 19, 2004.
- [3] R. Unnorsson, "Hit Detection and Determination in AE Bursts," in *Acoustic Emission – Research and Applications*, 2013, ch. Chapter 1.
- [4] T. B. Quy and J.-M. Kim, "Leak localization in industrial–fluid pipelines based on acoustic emission burst monitoring," *Measurement*, vol. 151, 2020, doi: 10.1016/j.measurement.2019.107150.
- [5] M. G. R. Sause, *In Situ Monitoring of Fiber-Reinforced Composites* (Springer Series in Materials Science). Switzerland: Springer International Publishing, 2016, pp. 621–624.
- [6] S. Seo, "A Review and Comparison of Methods for Detecting Outliers in Univariate Data Sets," ed, 2006.
- [7] H. Noh, S. Hong, and B. Han, "Learning Deconvolution Network for Semantic Segmentation," p. arXiv:1505.04366doi: 10.48550/arXiv.1505.04366.
- [8] N. Tomar. "Hands-on Transfer Learning with Keras and the VGG16 Model." LearnDataSci. <https://www.learndatasci.com/tutorials/hands-on-transfer-learning-keras/> (accessed Jul. 6th, 2023).
- [9] M. Schuster and K. K. Paliwal, "Bidirectional recurrent neural networks," *IEEE Transactions on Signal Processing*, vol. 45, no. 11, pp. 2673–2681, 1997, doi: 10.1109/78.650093.
- [10] M. Ghislieri, G. L. Cerone, M. Knaflitz, and V. Agostini, "Long short-term memory (LSTM) recurrent neural network for muscle activity detection," *J Neuroeng Rehabil*, vol. 18, no. 1, p. 153, Oct 21 2021, doi: 10.1186/s12984-021-00945-w.
- [11] 이상인, 김재영, 임순현, and 김종면, "장단기 메모리 순환 신경망을 이용한 음향방출 이벤트 검출," *한국비파괴검사학회 춘계학술대회 초록집*, p. 70, 2022.
- [12] 이상인, 김재영, 임기창, and 김종면, "웹 기반 유·가스 지하배관 결함 진단 시스템," *한국가스학회 봄 학술대회 논문집*, p. 89, 2021.
- [13] T. B. Quy, S. Muhammad, and J.-M. Kim, "A Reliable Acoustic EMISSION Based Technique for the Detection of a Small Leak in a Pipeline System," *Energies*, vol. 12, no. 8, 2019, doi: 10.3390/en12081472.

[영문 요약]

## Research on Acoustic Emission Testing Method Using Synthetic Signal Data and Deep Learning Models

Acoustic Emission(AE) inspection technology is widely used to ensure the safety and sustainability of various structures such as pipelines, bridges, aircraft, and ships. However, existing AE inspection methods have limitations due to performance restrictions based on environmental factors and the need for user experience-based environmental variable adjustments. To overcome these limitations, this study investigates a deep learning-based AE impulse signal detection method using synthetic signal data, proposing a new approach that addresses the issues with existing methods.

First, an AE synthetic signal data generation model that simulates various environmental conditions was developed. This model generates synthetic data considering the acoustic emission features that can occur under different conditions, providing rich data for deep learning algorithm training. During the training process of the deep learning-based AE impulse signal detection model, various network structures and deep learning techniques were experimented.

In the stage of verifying the utility of the trained model by applying it to actual pipeline inspections, the performance of the proposed method was evaluated in comparison with existing static threshold based method and Acoustic Emission Burst Monitoring(ABM) method. The proposed method demonstrated satisfactory inspection performance and improved several issues that arose with existing methods.

By utilizing deep learning algorithms, the dependence on environmental variable adjustments was reduced due to the absence of parameters, allowing for more accurate impulse signal detection in various environments. Furthermore, the deep learning-based method showed adaptive and stable performance even in noisy environments compared to existing methods.

In conclusion, this study proposes a deep learning-based acoustic emission impulse signal detection method using synthetic signal data, overcoming the limitations of existing inspection methods and contributing to improving the safety and sustainability of structures. This approach is expected to lay the groundwork for the development and application of AE inspection technology in various fields.